

Como Agregar e Não Influenciar Modelos - Controlando a Influência de Clientes no Aprendizado Federado Dinâmico

Rafael O. Jarczewski¹, Eduardo Cerqueira², Luiz F. Bittencourt¹,
Antonio A. F. Loureiro³, Leandro A. Villas¹, Allan M. de Souza¹

¹Universidade Estadual de Campinas, Brasil

²Universidade Federal do Pará, Brasil

³Universidade Federal de Minas Gerais, Brasil

rojarczewski@lrc.ic.unicamp.br, cerqueira@ufpa.br,
loureiro@dcc.ufmg.br, {bit, lvillas, allanms}@unicamp.br

Abstract. *Distributed systems have proven to be an essential approach for machine learning, especially in scenarios with many connected devices, such as the Internet of Things (IoT) and Smart Cities. However, the availability of these devices is crucial for effective training. It cannot be guaranteed throughout the training process due to limitations such as battery life, bandwidth, or compliance requirements. To address these challenges, we propose FedPIPC. This aggregation method leverages client participation as an influencing factor in the global model, combined with a knowledge preservation mechanism to mitigate the impacts of participation fluctuations during federated training. Empirical results show that the proposed solution improves the balance between accuracy and data transmission by up to 50% and reduces transmission volume by up to 89%, demonstrating its effectiveness in dynamic scenarios.*

Resumo. *Sistemas distribuídos têm se mostrado uma abordagem essencial para o aprendizado de máquina, especialmente em cenários com grande quantidade de dispositivos conectados, como a Internet das Coisas (IoT) e Cidades Inteligentes. No entanto, a disponibilidade desses dispositivos é crucial para um treinamento eficaz, e não é garantida durante todo o treinamento devido a limitações como bateria, largura de banda ou requisitos de conformidade. Para enfrentar esses desafios, propomos FedPIPC, um método de agregação que utiliza a participação dos clientes como fatores de influência no modelo global, combinado com um mecanismo de preservação de conhecimento para mitigar os impactos das oscilações na participação ao longo do treinamento federado. Os resultados empíricos indicam que a solução proposta melhora o equilíbrio entre precisão e transmissão de dados em até 50% e reduz o volume de transmissão em até 89%, comprovando sua eficácia em cenários dinâmicos.*

1. Introdução

A Inteligência Artificial (IA) vem se destacando como uma ferramenta de impacto positivo em diversas verticais da sociedade, incluindo cidades inteligentes e saúde digital [Reddy and Gadekallu 2023]. Contudo, tarefas realizadas pela IA, podem envolver informações sensíveis dos usuários, cuja transmissão pela rede e armazenamento remoto, acarretam riscos significativos para a privacidade dos dados. Neste contexto, o Aprendizado Federado (AF) emerge como uma solução de aprendizado de máquina distribuído

projetado para a mitigar os desafios associados ao acesso e transmissão de dados sensíveis em ecossistemas distribuídos [Capanema et al. 2025].

O AF envolve dois componentes principais, (i) o servidor, entidade central responsável pelo gerenciamento e agregação de conhecimento dos modelos e (ii) os clientes, que enviam as atualizações dos modelos locais treinados em seus dados. Esse ciclo, chamado Rodada de Comunicação (RC), é repetido até alcançar o objetivo do treinamento, como por exemplo uma acurácia pré-determinada. A quantidade de clientes selecionada para o treinamento em cada RC é limitada. Para lidar com essa restrição, diversos estudos sugerem a seleção de um subconjunto de clientes a cada iteração [Jee Cho et al. 2022, Souza et al. 2023, de Souza et al. 2024, ?]. No entanto, essas soluções não consideram a participação dinâmica e não-estacionária de dispositivos IoT móveis, como *smartphones* e *smartwatches* onde sua disponibilidade é esporádica devido a problemas de conectividade com a Internet ou limitação de energia [Jarczewski et al. 2024]. Essa característica introduz incertezas no processo de seleção e, conseqüentemente, participação dos dispositivos, resultando em um ambiente dinâmico, imprevisível e não estacionário durante o processo de treinamento [Yan et al. 2023].

O AF enfrenta desafios significativos devido à heterogeneidade dos dispositivos e à natureza Não Independente e Identicamente Distribuídos (Não-IID) dos dados, fatores que contribuem para a instabilidade durante o treinamento, a qual decorre da dinâmica dos recursos computacionais e de comunicação, bem como características dos dados locais. Dispositivos IoT com capacidades limitadas podem não processar atualizações de forma eficiente, enquanto dados altamente divergentes entre os clientes prejudicam a uniformidade do aprendizado [Zhu et al. 2021].

As necessidades e os requisitos específicos dos clientes podem influenciar diretamente sua disponibilidade e permanência ao longo do processo de treinamento, tornando essencial, o estímulo à sua participação. Yae Jee Cho *et al.* [Cho et al. 2024] apresentam um ambiente em que a participação dos dispositivos é determinada pelo nível de *atração* que o modelo global exerce sobre o cliente. Assim, caso o modelo global não satisfaça os requisitos de desempenho mínimo, o cliente opta por não participar do treinamento [Cho et al. 2024]. Essa dinâmica introduz uma variável adicional no treinamento, pois, após as RC, a participação no treinamento torna-se volátil. Clientes antes desinteressados podem passar a perceber vantagens em contribuir com o treinamento do modelo global, contribuindo essa, que pode levar a clientes que estavam contribuindo pararem de ajudar no treinamento pois o modelo global deixa de representar seus dados. Problema que torna visível a necessidade de métodos para equilibrar as contribuições de clientes durante o treinamento.

Os desafios do AF relacionados às características heterogêneas dos clientes e dos dados tornam complexa a preservação do conhecimento global. O modelo precisa alcançar um equilíbrio entre a adaptação a padrões específicos dos dados locais e a manutenção da capacidade de generalização, evitando que o aprendizado seja enviesado ou com baixa acurácia. Yao, Dezhong et al. [Yao et al. 2024] classificam os impactos desse desafio em duas categorias: **Esquecimento Local (EL)** e **Esquecimento Global (EG)**. No primeiro caso, a construção do modelo global por meio da agregação das atualizações dos clientes resulta em uma representação baseada no consenso entre os participantes, o que pode levar à perda de padrões específicos dos dados locais. Por outro lado, no segundo caso, ajustar o modelo aos dados particulares de cada cliente compro-

mete sua capacidade de generalização. Essa limitação se torna mais evidente quando os conjuntos de dados locais divergem significativamente da média, dificultando que o modelo adaptado capture padrões globais de maneira eficaz [Yao et al. 2024]. Portanto, é essencial desenvolver estratégias que preservem o conhecimento adquirido para mitigar os problemas de esquecimento mencionados.

Em cenários dinâmicos e móveis, a participação dos clientes apresenta um desafio adicional e contribuem para o enviesamento do modelo global, pois os dispositivos com melhores condições e disponibilidade participam com mais frequência do AF [Xiang et al. 2024]. Considerar a influência dos clientes para o modelo global é fundamental para limitar vieses de clientes mais frequentes. Além disso, é crucial preservar o conhecimento adquirido previamente pelo modelo global, a fim de garantir a representatividade dos padrões aprendidos anteriormente.

Este artigo apresenta Federação com Ponderação através de Influência e Preservação do Conhecimento (FedPIPC)¹, um método eficiente para cenários de dados heterogêneos com participação dinâmica. Entre as contribuições deste trabalho estão: *i*) Propor um algoritmo de agregação ponderado pela quantidade de contribuições realizadas pelos clientes nos cenários de participação dinâmica; *ii*) Método flexível que pode ser incorporado a outros métodos de agregação, bastando adicionar novos fatores de influência relacionados às preferências dos clientes; e *iii*) Mecanismo de prevenção do conhecimento durante o processo de agregação. Essa integração permite otimizar o uso de recursos, reduzir vieses no modelo global e melhorar sua capacidade de generalização reduzindo o consumo de banda em até 89% e aumentando valor de *tradeoff* entre acurácia e dados transmitidos das RC em 50%.

O restante deste trabalho está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 introduz a definição do problema. A Seção 4 descreve a ponderação por participação e preservação do conhecimento. A Seção 5 discute os resultados. A Seção 6 conclui o artigo e apresenta os trabalhos futuros.

2. Trabalhos Relacionados

Existem diversos desafios em lidar com a preservação do conhecimento e participação dinâmica no AF. Esta seção discute os trabalhos da literatura que investigam a preservação do conhecimento local e global durante o treinamento federado. Além disso, apresenta diferentes estratégias que lidam com a participação dinâmica e heterogênea.

Tian Li *et al.* desenvolveram o FedProx, uma extensão do FedAVG para lidar com a heterogeneidade estatística e de sistemas no AF, incorporando um termo proximal que restringe as atualizações locais, evitando que os modelos individuais divirjam do modelo global. Essa abordagem contribui para preservação do conhecimento global ao mitigar os efeitos da divergência causada por dados Não-IID entre dispositivos participantes [Li et al. 2020].

Já o trabalho de Yao *et al.* propõe o pFedAMF, uma proposta de personalização para o AF focado na preservação e fusão adaptativa de conhecimento global e local [Yao et al. 2024]. Diferente de métodos tradicionais que negligenciam o esquecimento do conhecimento durante a agregação e atualização dos modelos, o pFedAMF possui mecanismos para preservar o modelo global antes do treinamento local além de manter um

¹<https://github.com/rafaeloj/FedPIPC>

histórico do estado local antes da agregação. Dessa forma, através de uma matriz adaptativa de fusão de conhecimento, integra informações globais, locais e históricas de forma personalizada.

Outra vertente estuda estratégias para mitigar os problemas provenientes das mudanças temporais nas distribuições dos dados dos clientes durante o treinamento federado. Myeongkyun Kang *et al.* introduz o FedNN, uma abordagem projetada para mitigar os efeitos provenientes do Concept Drift (CD), onde os clientes possuem dados com diferentes estilos, mas compartilham as mesmas classes de rótulos ao longo do treinamento. Para enfrentar esse desafio, o FedNN emprega *Weight Normalization (WN)* para estabilizar as ativações ao reparametrizar os pesos com média zero e variância unitária, e *Adaptive Group Normalization (AGN)* para ajustar dinamicamente a normalização das características intermediárias, promovendo consistência nas ativações do conhecimento global evitando diluição de informações locais durante a agregação [Kang et al. 2024].

Apesar de abordagens como o FedProx, pFedAMF e FedNN apresentarem avanços significativos na mitigação da heterogeneidade e na preservação do conhecimento global no AF, todas compartilham a limitação de não considerar a participação dinâmica e não estacionária dos clientes. A ausência de estratégias para lidar com flutuações na disponibilidade dos dispositivos ao longo do treinamento pode introduzir vieses na agregação dos modelos locais, comprometendo a eficiência do processo de aprendizado e a generalização do modelo global.

Estudos recentes investigam os impactos que a indisponibilidade do cliente durante o treinamento pode ter na federação. O trabalho de Xiang *et al.* propõe o FedAWE como uma solução para lidar com a indisponibilidade heterogênea e não estacionária de clientes [Xiang et al. 2024]. Através do *Adaptive Innovation Echoing*, que compensa as atualizações locais perdidas devido à indisponibilidade, e *Implicit Gossiping*, que difunde equilibradamente as atualizações locais entre os clientes ativos sem exigir conhecimento prévio da dinâmica de disponibilidade. Assim permite corrigir vieses causados pela participação irregular dos clientes e mantém a eficiência computacional com baixo custo de memória.

Crawshaw e Liu propõem o Amplified Scaffold, uma extensão do algoritmo SCAFFOLD voltada para participação periódica e não estacionária dos clientes [Crawshaw and Liu 2024]. A abordagem introduz atualizações amplificadas e variáveis de controle ajustadas com base em janelas de participação, permitindo reduzir significativamente o custo de comunicação e aumentar a robustez frente à heterogeneidade dos dados. Essa estratégia melhora a eficiência do treinamento, garantindo convergência mais rápida mesmo em cenários com participação cíclica e não independente.

Embora abordagens como o FedAWE e o Amplified SCAFFOLD sejam eficazes em mitigar os impactos da participação não estacionária de clientes no Aprendizado Federado, ambas desconsideram fatores importantes, como as preferências individuais e o nível de interesse dos clientes em participar do treinamento. A ausência de mecanismos que avaliem a motivação ou os benefícios percebidos pelos dispositivos participantes pode levar ao uso ineficiente de recursos de rede, ao selecionar clientes disponíveis que não têm incentivo para contribuir com o modelo global. Essa limitação restringe o potencial de personalização e otimização do desempenho do modelo.

O trabalho de Yae Jee Cho *et al.* propõe o MaxFL, uma abordagem para Aprendi-

Tabela 1. Comparação entre os problemas atacados versus FedPIPC

Solução	Problemas Atacados			
	Não-IID	Esquecimento Catastrófico	Mudança temporal	Cientes Não-Estacionários
FedProx	x			
pFedAMF	x	x		
FedNN	x		x	
FedAWE	x			x
Applified Scaffold	x			x
MaxFL	x			x
FedPIPC	x	x	x	x
FedPIPC*	x	x	x	x

zado Federado que busca maximizar a atração pelo modelo global (*Global Model Appeal* - GM-Appeal), ou seja, aumentar o número de clientes que consideram o modelo global satisfatório em relação aos seus requisitos individuais [Cho et al. 2024]. O MaxFL utiliza um objetivo de otimização que ajusta dinamicamente o peso das atualizações dos clientes com base no quão bem o modelo global atende às necessidades de cada cliente dessa forma incentiva uma maior participação ao adaptar o modelo global para ser mais atrativo. Apesar de considerar a insatisfação dos clientes como um fator crítico para a participação, o MaxFL não incorpora mecanismos de incentivo ou custo de participação, desconsiderando fatores como o custo computacional ou consumo de energia.

A Tabela 1 sumariza os problemas atacados pelos trabalhos relacionados em comparação com FedPIPC. Também comparamos uma variação FedPIPC* que adiciona um tratamento similar ao FedProx no lado do cliente para lidar com dados heterogêneos. Motivados pelas limitações identificadas na literatura, propomos essas duas abordagens, que transformam a participação dos clientes em Fatores de Influência no modelo global, equilibrando as contribuições e mitigando os vieses de clientes com maior participação. Além disso, FedPIPC oferece flexibilidade ao permitir a integração desse fator de influência com outros métodos de ponderação e introduz um método de preservação de conhecimento na agregação, utilizando uma taxa de aprendizado dinâmica que reduz os impactos bruscos entre rodadas de comunicação.

3. Definição do problema

Tradicionalmente cenários do AF são definidos da seguinte forma: Dado um conjunto C de clientes na federação, em cada Rodada de Comunicação (RC), $t \in \{1, 2, 3, \dots, T\}$, um subconjunto $S \subseteq C$ é selecionado. Cada cliente i tem um base de dados d_i de forma que $\mathcal{D} = \bigcup_{i \in C} d_i$ representa a distribuição global dos dados. Os clientes selecionados recebem o modelo global w_g^t e realizam o treinamento em seus dados d_i . Então, cada cliente i retorna as atualizações do modelo para o servidor. No final do RC t , o modelo global é atualizado através da média ponderada das atualizações enviadas pelos clientes de acordo com a Equação (1).

$$w_g^{t+1} = \sum_{i=1}^{|S|} \frac{|d_i|}{|D|} w_i^t \quad (1)$$

Assim, o objetivo principal em AF é minimizar a seguinte função objetivo $F(w_g)$:

$$\min_w F(w_g) \quad \text{onde} \quad F(w_g) = \sum_{i=1}^{|C|} \frac{|d_i|}{|D|} \mathcal{L}(w_g; x_i, y_i) \quad (2)$$

onde w_g é o modelo global, \mathcal{L} é a função de perda, x_i e y_i , respectivamente, são entradas de dados e rótulos do conjunto de dados d_i para cada cliente.

3.1. Fluxo de Participação

A participação dinâmica ou não estacionária dos clientes é definida de varias formas na literatura [Cho et al. 2024, Crawshaw and Liu 2024, Xiang et al. 2024]. Para este trabalho, consideramos os requisitos e necessidades dos clientes, que possuem recursos limitados (bateria, capacidade de processamento, conectividade) e, portanto, participam do treinamento apenas quando percebem um benefício direto. Esse benefício pode ser avaliado pela comparação entre o desempenho do modelo global w_g e do modelo local w_i do cliente, medido por meio da função de perda \mathcal{L} aplicada aos seus dados locais (x_i, y_i) . Portanto, a decisão de participação é modelada pela seguinte equação:

$$q_i^t = \begin{cases} 0, & \text{se } \mathcal{L}(w_g; x_i, y_i) - \mathcal{L}(w_i; x_i, y_i) > 0 \\ 1, & \text{se } \mathcal{L}(w_g; x_i, y_i) - \mathcal{L}(w_i; x_i, y_i) \leq 0 \end{cases} \quad (3)$$

onde o cliente i participa do treinamento ($q_i^t = 1$) apenas se o modelo global apresentar desempenho igual ou superior ao seu modelo local, ou seja, se $\mathcal{L}(w_g; x_i, y_i) \leq \mathcal{L}(w_i; x_i, y_i)$. Caso contrário, ele opta por não participar ($q_i^t = 0$). Essa abordagem reflete o comportamento racional e auto interessado do cliente, que busca otimizar seus próprios recursos, participando somente quando há vantagem. Esse mecanismo torna o sistema dinâmico, forçando o servidor a adaptar o modelo global para torná-lo mais atrativo.

A decisão de participação, introduz uma dinâmica natural no sistema, onde os clientes alternam entre participar ou não com base em seus próprios interesses. Esse comportamento resulta em diferentes cenários de participação, que podem ser analisados para entender melhor como a variação no engajamento impacta o treinamento.

A interação dos clientes pode ser categorizada em três estados principais. O primeiro, descrito na Figura 1(a), onde os conjuntos de clientes participantes e não participantes são de tamanho igual. Esse estado serve como uma linha de base para análise porque permite a identificação de um subconjunto significativo de clientes participantes para abordar questões relacionadas à não participação e elaborar estratégias para encorajar clientes não participantes a participar.

A Figura 1(b) representa o segundo estado, que é o estado desejado, onde o número de clientes participantes excede o número de não participantes. Neste cenário, o modelo global se beneficia do aumento da diversidade, permitindo ações para mitigar vieses causados por taxas de participação variáveis entre clientes. A maior representação de clientes participantes aumenta a robustez e a justiça do modelo.

O terceiro estado, ilustrado na Figura 1(c), deve ser evitado e ocorre quando a quantidade de clientes não querem participar da federação supera os interessados. Nesse caso, os desafios da representatividade aumentam devido a um subconjunto menor de clientes ativos, levando a menos amostras para treinamento. Isso dificulta os esforços para envolver clientes não participantes e prejudica a eficácia geral do modelo.

FedPIPC evita o estado descrito na Figura 1(c) enquanto busca atingir o estado da Figura 1(b), integrando o conhecimento histórico do modelo global com uma agregação ponderada baseada na frequência e relevância da participação dos clientes. Essa estratégia tem como objetivo mitigar vieses causados por clientes com alta



- (a) O ponto de partida com o conjunto de clientes participantes e não participantes é do mesmo tamanho.
- (b) O caso desejado, onde o conjunto de participantes se torna maior que o de não participantes.
- (c) O caso a ser evitado, onde a quantidade de clientes que querem participar é maior do que os que não querem participar da federação.

Figura 1. Casos que encontramos ao trabalhar com a participação dinâmica do cliente.

frequência de participação, promovendo uma contribuição mais equilibrada e justa para o modelo global.

4. Federação com Ponderação através de Influência e Preservação do Conhecimento

FedPIPC foi desenvolvido com base em dois princípios essenciais: *i)* Considerar participação dinâmica dos clientes, motivada por suas preferências individuais e pelo desempenho comparativo entre seus modelos locais e o modelo global; *ii)* a preservação do conhecimento global para garantir a estabilidade do modelo durante o treinamento. Esses pilares são implementados por meio de um mecanismo de agregação ponderada, e por técnicas de preservação do conhecimento que limitam mudanças abruptas no modelo global. A Subseção 4.1 descreveremos o processo de agregação e ponderação, enquanto a Subseção 4.2 aborda as estratégias para preservar o conhecimento adquirido ao longo do treinamento.

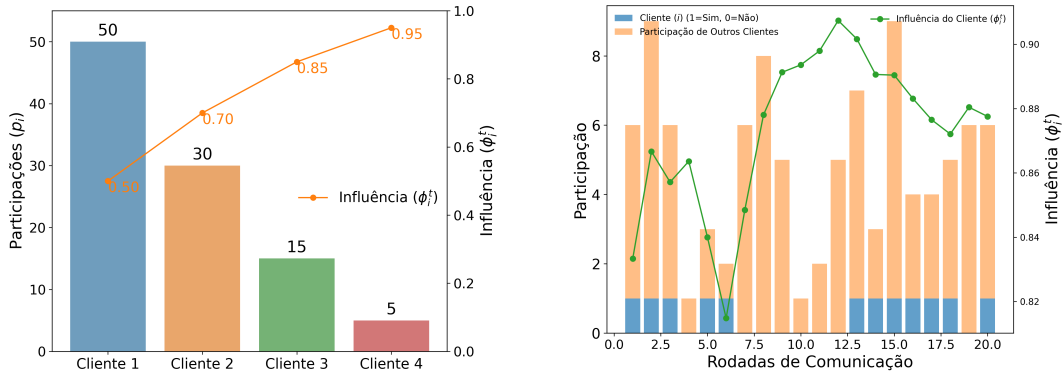
4.1. Transformando participação em influência

Clientes com maior frequência de disponibilidade criam um viés no modelo global, direcionando-o para um mínimo local. Para mitigar esse efeito, propomos um Fator de Influência (FI) ϕ_i para cada cliente i definido através razão entre a quantidade de participações totais $\mathcal{P} = \sum_{i=1}^C p_i$ em relação a quantidade de vezes que ele participou p_i^t como mostrado na Equação (4).

$$\phi_i^t = \left(1 - \frac{p_i}{\mathcal{P}}\right) \quad (4)$$

Assim, através da Equação (5) é possível identificar a contribuição do cliente i até o round t com o modelo global e reduzir gradualmente sua influência, permitindo que outros clientes com menor contribuições tenham maior influência.

$$w_g = \sum_{i=1}^{|C|} \frac{|d_i|}{|D|} w_i^t \phi_i^t \quad (5)$$



(a) Representação do comportamento do ϕ entre clientes em uma rodada t . (b) Representação do comportamento do ϕ de um cliente i ao longo das rodadas de comunicação.

Figura 2. Exemplo do comportamento da distribuição do ϕ ao longo do treinamento federado.

A Figura 2(a), mostra o comportamento do ϕ em relação a quantidade de participações totais. Para os clientes que tem a menor participação o valor de ϕ é maior, e ao contrário quanto maior for sua participação menor será o seu valor. Esse comportamento leva clientes frequentes a terem menor influência, mas não nula, na agregação permitindo que os clientes com menor frequência tenham maior FI.

A Figura 2(b) demonstra o comportamento dinâmico de ϕ para um cliente ao logo da federação. Note que nas rodadas onde o cliente não participa seu FI começa a aumentar, entretanto conforme sua frequência de participação cresce seu ϕ começa a reduzir. Em cenários de participação não estacionária e dinâmica, clientes com menor frequência de participação podem ter o seu conhecimento rapidamente esquecido. A ideia chave aqui é impulsionar o conhecimento desses clientes para retardar o esquecimento.

4.2. Preservação do conhecimento

Em ambientes com dados Não-IID, além do mecanismo de seleção causar mudanças nas distribuições e comprometer a estabilidade da agregação, a situação se agrava quando clientes que nunca participaram do treinamento começam a contribuir com novos dados e distribuições. Esse problema é similar ao fenômeno conhecido como CD [Gama et al. 2014], que ocorre quando um modelo de aprendizado de máquina centralizado é exposto a novas distribuições de dados. No aprendizado centralizado, existem diversas técnicas para mitigar os efeitos do CD [De Lange et al. 2022, Criado et al. 2022]. FedPIPC baseia-se nessas técnicas, através da utilização do conhecimento prévio adquirido em rodadas anteriores para aumentar a estabilidade e reduzir as oscilações durante a agregação dos modelos dos clientes.

Como novos clientes podem possuir dados pertencentes a distribuições não vistas pela federação e causar instabilidade no treinamento, é necessário elaborar maneiras que permitam sua participação sem prejudicar o treinamento realizado até o momento. Dessa forma, propomos um método para reter o conhecimento aprendido até o momento garantindo que os clientes novos tenham uma contribuição efetiva sem prejudicar a estabilidade do modelo global.

Suponha que temos um modelo global w_t^t composto por um subconjunto de clien-




Figura 3. Exemplo ilustrativo do comportamento do λ ao longo de iterações com diferentes valores de média e desvio padrão.

tes $S_i \in C$, o novo modelo global w_Ω^{t+1} é composto pelo subconjunto $S_\Omega \in C$ na rodada $t + 1$. A imprevisibilidade da participação dos clientes em conjunto com algoritmos de seleção faz com que $S_i \neq S_\Omega$, implicando uma divergência de padrões e conhecimento dos dados entre os modelos w_i^t e w_Ω^{t+1} . Assim, utilizamos uma redução no deslocamento ponderado do modelo w_i^t em direção ao modelo w_Ω^{t+1} através da variabilidade entre os pesos das camadas definido pela Equação (6).

$$w_g^{t+1} = w_i^t + \lambda \Delta w \quad (6)$$

de forma que, $\Delta w = w_\Omega^{t+1} - w_i^t$, e w_Ω^{t+1} é calculado através da Equação 5. Para λ propomos um valor baseado na variabilidade estatística entre os pesos das camadas definida pela Equação 7.

$$\lambda = \frac{1}{1 + \frac{\sigma_{\Delta w}}{\bar{\Delta w}}} \quad (7)$$

onde $\sigma_{\Delta w}$ e $\bar{\Delta w}$ representam, respectivamente, o desvio padrão e a média dos pesos das camadas. Assim, ao longo das rodadas se os pesos começarem a apresentar $\sigma_{\Delta w}$ muito alto, o valor do λ é reduzido, de mesmo modo, se o valor do desvio padrão for alto, a influência será maior. A Figura 3 ilustra um exemplo do comportamento do λ . Perceba que, conforme o $\sigma_{\Delta w}$ aumenta o λ é reduzido e, dessa forma, grandes alterações entre um modelo global e outro são suavizadas de acordo com a variabilidade entre os pesos sem atrapalhar o aprendizado.

O Algoritmo 1 apresenta o fluxo do FedPIPC que é dividido em três partes. Na primeira etapa é realizado o cálculo dos pesos de acordo com Equação (4) para cada cliente. Entre as Linhas 6-7, a segunda etapa realiza a agregação das atualizações dos clientes através da Equação (5). Por fim, na terceira etapa, na Linha 9 encontramos a diferença entre o modelo global w_g^t e o novo modelo w_Ω^{t+1} , na Linha 10 é calculado o valor do λ e o modelo w_g^{t+1} é atualizado de acordo com a Equação (6) na Linha 11.

Ao integrar um mecanismo de agregação ponderada, que equilibra a influência de clientes com diferentes níveis de participação, e técnicas de preservação do conhecimento que estabilizam o modelo global diante de mudanças nas distribuições de dados, FedPIPC garante maior robustez e generalização do modelo. Essa combinação não apenas reduz vieses causados por participações frequentes, mas também assegura que novos clientes possam contribuir de forma efetiva sem comprometer o desempenho do modelo. Dessa forma, FedPIPC promove um treinamento federado mais eficiente, estável e adaptável a

Algorithm 1 Algoritmo de agregação

- 1: **Server executa:**
 - 2: **Passo 1: Calcula as influências de participação**
 - 3: $\mathcal{P} \leftarrow \sum_{i=1}^N p_i$
 - 4: **for** cada $i \in \{1, 2, \dots, N\}$ **do**
 - 5: $\phi_i \leftarrow (1 - \frac{p_i}{\mathcal{P}})$

 - 6: **Passo 2: Agregação das atualizações dos clientes**
 - 7: $w_{\Omega}^{t+1} \leftarrow \sum_{i=1}^{|C|} \frac{|d_i|}{|C|} \mathcal{L}(w_g; x_i, y_i) \phi_i$

 - 8: **Passo 3: Aplicação do mecanismo de estabilidade**
 - 9: $\Delta w_g^t \leftarrow w_{\Omega}^{t+1} - w_g^t$
 - 10: $\lambda_i \leftarrow \frac{1}{1 + \frac{\Delta w}{\sigma_{\Delta w}}}$
 - 11: $w_g^{t+1} \leftarrow w_g^t + \lambda \Delta w^t$ \triangleright *Atualização dos pesos agregados com um fator de suavização*
-

ambientes com participação não estacionária e dinâmica, otimizando o uso de recursos e melhorando a qualidade do modelo global.

5. Análise de Desempenho

Esta seção apresenta a avaliação do FedPIPC em relação aos trabalhos da literatura. Durante a Seção 5.1 será apresentado o ambiente e configurações dos experimentos. Logo após, a Seção 5.2 analisa o desempenho de modelo, o *overhead* de comunicação e o *trade-off* entre desempenho e comunicação.

5.1. Configurações dos experimentos

Soluções da Literatura. Realizamos a comparação com os métodos *FedAvg* e *FedProx* com $\mu = 2$ [McMahan et al. 2016, Li et al. 2020]. Além disso, comparamos nossa solução com abordagens que incorporam técnicas de preservação do conhecimento durante o treinamento, como o *FedAvgM* (com *momentum* de 0,8 e taxa de aprendizado de 0,3) e o *FedYogi* (com $\eta = 10^{-2}$, $\eta_l = 0,0316$, $\beta_1 = 0,9$, $\beta_2 = 0,99$ e $\tau = 10^{-3}$), que aplica momento adaptativo na agregação, de forma similar ao FedPIPC. Adicionalmente, investigamos uma adaptação do FedPIPC* integrada ao treinamento proximal dos clientes similar ao do algoritmo *FedProx*.

Base de dados, e modelos. Para o experimentos, utilizamos 3 base de dados compostas por imagens de números e roupas, USPS, MNIST e FMNIST ². Para distribuição dos dados utilizamos Flower Datasets ³ através da distribuição de Dirichlet, com alpha de 0.1 para MNIST e FMNIST e para USPS o alpha de 0.2. Usamos uma Deep Neural Network (DNN) composta por 6 camadas densas de 256, 128, 64, e 32 unidades, respectivamente e 1 camadas de *dropout* entre as duas primeiras e entre as duas últimas camadas com otimizador SGD com *clipvalue* de 1.0. Para cada experimento utilizamos o *kernel* inicializador LecunNormal com 50 clientes e 100 rodadas de comunicação, utilizando *framework* Flower [Beutel et al. 2022].

Métricas. Para avaliar nossa solução, utilizamos três métricas. **Acurácia média distribuída** atingida na última RC, o cálculo é realizado de forma distribuída ao final de

²<https://huggingface.co/flwrlabs>

³<https://flower.ai/docs/datasets/>

cada rodada, onde o modelo global é enviado para o cliente e testado em uma base de dados de teste não vista durante o treinamento. **Desperdício de dados transmitidos** é calculado através da soma dos dados enviados para os clientes que decidem não utilizar o modelo global através da Equação (3) visto que, eles não colaboraram com a agregação e nem foram convencidos a participar. Além disso, investigamos o **trade-off**, que representa a relação entre o volume total de dados enviados e a acurácia obtida ao final da federação.

5.2. Resultados

Para realizar os experimentos, criamos uma seleção randômica com 20% dos clientes para cada uma das 100 rodadas de comunicação e todas soluções selecionam os mesmos clientes em cada uma das rodadas. O objetivo é garantir que as soluções executem nas mesmas condições de seleção, dessa forma, cada uma das abordagens iniciam no mesmo ponto e percorrem o mesmo caminho de seleção, assim conseguimos comparar os comportamentos entre sistemas federados.

Tabela 2. Resultados das acurácias atingidas para cada solução.

Base de Dados	Abordagens					
	FedAvg	FedAvgM	FedYogi	FedProx	FedPIPC	FedPIPC*
MNIST	0,93	0,95	0,94	0,93	0,94	0,91
FMNIST	0,78	0,81	0,69	0,74	0,80	0,74
USPS	0,91	0,92	0,77	0,91	0,87	0,85

A Tabela 2 apresenta o acurácia média das abordagens avaliadas nas três bases de dados, com os melhores resultados destacados em negrito. Embora o FedAvgM tenha alcançado os maiores índices de desempenho em todos os cenários, é crucial destacar que a acurácia não é o único fator determinante na avaliação de sistemas distribuídos. Em ambientes com restrições de largura de banda, o elevado custo de comunicação necessário para atingir altos níveis de desempenho pode comprometer a viabilidade do treinamento de modelos. Portanto, a análise do volume de dados transmitidos, especialmente aqueles desnecessários ou redundantes, torna-se essencial. A eficiência de um sistema deve ser avaliada de forma abrangente, considerando o equilíbrio entre desempenho e consumo de recursos, a fim de garantir soluções sustentáveis e escaláveis em ambientes distribuídos.

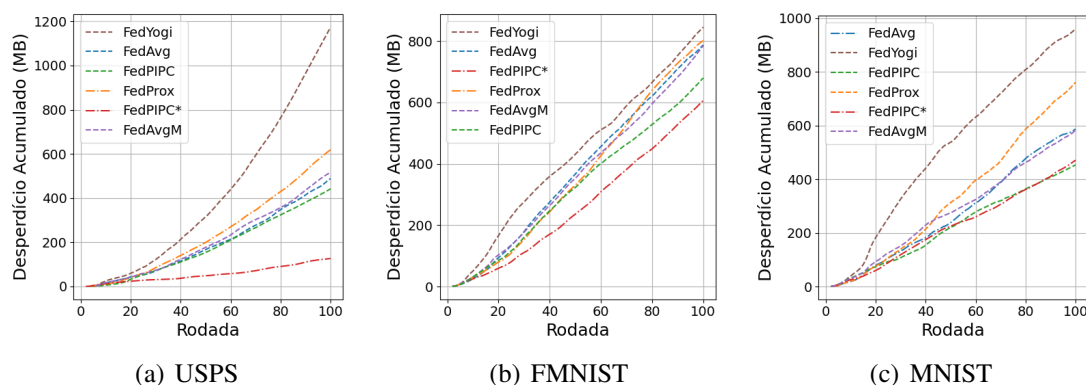


Figura 4. Desperdício de dados transmitidos acumulados ao longo das RC.

Na Figura 4 são apresentados valores totais acumulados de desperdício de banda transmitido durante toda federação. É possível identificar que, apesar do FedAvgM atingir

um desempenho superior, o custo pode ser de até de 89% mais alto que o FedPIPC*. Custo este, que muitas vezes é inviável em cenários reais e de grande escala, tornando mais atrativas as abordagens que sacrificam alguns percentuais de desempenho a fim de reduzir as despesas.




Figura 5. Trade-off entre acurácia e desperdício de dados transmitidos

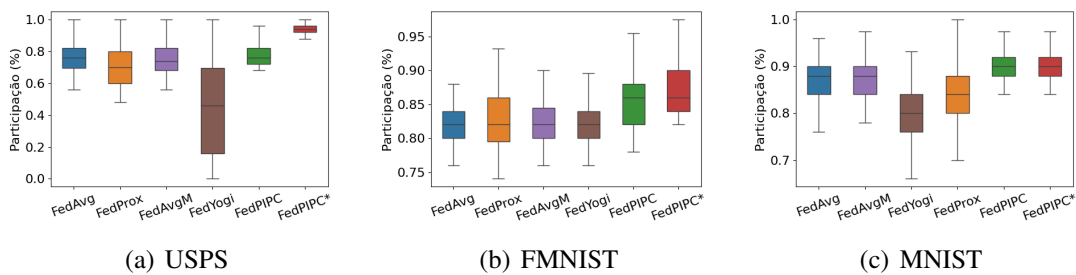


Figura 6. Índice de participação dos clientes durante o treinamento federado.

A Figura 5 ilustra claramente o trade-off entre o desempenho obtido e a quantidade de dados redundantes transmitidos. A FedPIPC demonstra superioridade em relação às demais abordagens, apresentando uma eficiência entre 3% e 50% superior, dependendo do cenário avaliado. Esse resultado é atribuído ao mecanismo otimizado de ponderação por influência, que assegura a participação efetiva de clientes com menor contribuição, ao mesmo tempo em que preserva de forma estratégica as contribuições anteriores, evitando seu esquecimento rápido. Esse equilíbrio contribui para um desempenho global mais robusto e eficiente do sistema.

A Figura 6 ilustra a variação de participação no sistema federado. Tanto a solução FedPIPC quanto a FedPIPC* apresentam um Intervalo Interquartil (IQR) de 0,04, evidenciando maior estabilidade em comparação com os métodos da literatura. Essa estabilidade é reforçada pelos valores de desvio padrão e variância: para a FedPIPC, os valores são 0,028 e 0,0008, respectivamente; já para a FedPIPC*, os valores correspondem a 0,0295 e 0,007. Em contraste, as soluções da literatura alcançaram até um IQR de 0,06, desvio padrão de 0,038 e variância de 0,001, indicando uma maior instabilidade.

Com os resultados apresentados, é possível concluir que: (i) ponderação por influência permite que clientes com frequências de participação diferentes contribuam de forma mais igualitária; (ii) a preservação do conhecimento garante maior participação durante o treinamento; (iii) FedPIPC consegue reduzir os custos de comunicação pois torna-se mais atrativo para os clientes por conta da sua preservação do conhecimento e

ponderação por influência; e (iv) é possível impulsionar ainda mais suas vantagens combinando com mecanismos de treinamento ao lado do cliente.

6. Considerações finais

Este artigo apresentou FedPIPC como um novo mecanismo de agregação para o AF em ambientes com a participação de clientes de forma dinâmica. FedPIPC é composto por dois critérios-chave: um novo fator influência no modelo global com base na participação dos clientes durante o treinamento, também é incorporado a preservação do conhecimento durante a agregação.

Resultados empíricos mostram que FedPIPC reduz os custos de comunicação em até 89% comparado ao FedAvgM nesses cenários e se apresenta como uma técnica promissora para ambientes de participação dinâmica, além de aumentar o *trade-off* da federação entre desempenho e dados transmitidos em até 50% comparado ao FedYogi.

Também é crucial destacar que soluções como FedPIPC são adequadas para cenários que não exigem alta precisão. Podemos categorizar esses casos em críticos e não críticos: os críticos envolvem, por exemplo, saúde e mobilidade, onde riscos podem resultar em problemas graves, enquanto cenários como recomendações de palavras ou reconhecimento de emoções podem se beneficiar com essa abordagem. Trabalhos futuros irão analisar cenários adicionais de participação dinâmica de clientes, incluindo a adição de mudanças de distribuições nos clientes, como CD, objetivando entender o comportamento da solução em domínios não vistos durante o treinamento.

7. Agradecimentos

Este projeto foi apoiado pelo Ministério da Ciência, Tecnologia e Inovações, com recursos da Lei nº 8.248, de 23 de outubro de 1991, no âmbito do PPI-SOFTEX, coordenado pela Softex e publicado Arquitetura Cognitiva (Fase 3), DOU 01245.003479/2024-10. Este trabalho foi parcialmente patrocinado pelo projeto #23/00673-7, São Paulo Instituto de Pesquisa (FAPESP), CNPq projeto #405940/2022-0 e CAPES projeto #88887.954253/2024-00 e PIND UNICAMP projeto #519.287

Disponibilidade de Artefatos

Todos os códigos utilizados e as configurações de ambiente necessárias para replicabilidade dos experimentos executados neste artigo estão disponíveis publicamente através da plataforma Github⁴.

Referências

- Beutel, D. J., Topal, T., Mathur, A., Qiu, X., Fernandez-Marques, J., Gao, Y., Sani, L., Li, K. H., Parcollet, T., de Gusmão, P. P. B., and Lane, N. D. (2022). Flower: A friendly federated learning research framework.
- Capanema, C. G. S., de Souza, A. M., da Costa, J. B. D., Silva, F. A., Villas, L. A., and Loureiro, A. A. F. (2025). A novel prediction technique for federated learning. *IEEE Transactions on Emerging Topics in Computing*, 13(1):5–21.
- Cho, Y. J., Jhunjunwala, D., Li, T., Smith, V., and Joshi, G. (2024). Maximizing global model appeal in federated learning. *Transactions on Machine Learning Research*.

⁴<https://github.com/rafaelobj/FedPIPC>

- Crawshaw, M. and Liu, M. (2024). Federated learning under periodic client participation and heterogeneous data: A new communication-efficient algorithm and analysis. In *Advances in Neural Information Processing Systems*.
- Criado, M. F., Casado, F. E., Iglesias, R., Regueiro, C. V., and Barro, S. (2022). Non-iid data and continual learning processes in federated learning: A long road ahead. *Information Fusion*, 88:263–280.
- De Lange, M., Aljundi, R., Masana, M., Parisot, S., Jia, X., Leonardis, A., Slabaugh, G., and Tuytelaars, T. (2022). A continual learning survey: Defying forgetting in classification tasks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7):3366–3385.
- de Souza, A. M., Maciel, F., da Costa, J. B., Bittencourt, L. F., Cerqueira, E., Loureiro, A. A., and Villas, L. A. (2024). Adaptive client selection with personalization for communication efficient federated learning. *Ad Hoc Networks*, 157:103462.
- Gama, J. a., Žliobaitundefined, I., Bifet, A., Pechenizkiy, M., and Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Comput. Surv.*, 46(4).
- Jarczewski, R. O., Cerqueira, E., Bittencourt, L. F., Loureiro, A. A. F., Villas, L. A., and de Souza, A. M. (2024). Let’s federate - effective communication strategy for dynamic client participation. In *2024 International Conference on Machine Learning and Applications (ICMLA)*, pages 361–368.
- Jee Cho, Y., Wang, J., and Joshi, G. (2022). Towards understanding biased client selection in federated learning. In Camps-Valls, G., Ruiz, F. J. R., and Valera, I., editors, *Proceedings of The 25th International Conference on Artificial Intelligence and Statistics*, volume 151 of *Proceedings of Machine Learning Research*, pages 10351–10375. PMLR.
- Kang, M., Kim, S., Jin, K. H., Adeli, E., Pohl, K. M., and Park, S. H. (2024). Fednn: Federated learning on concept drift data using weight and adaptive group normalizations. *Pattern Recognition*, 149:110230.
- Li, T., Sahu, A. K., Zaheer, M., Sanjabi, M., Talwalkar, A., and Smith, V. (2020). Federated optimization in heterogeneous networks. *Proceedings of Machine learning and systems*, 2:429–450.
- McMahan, H. B., Moore, E., Ramage, D., and y Arcas, B. A. (2016). Federated learning of deep networks using model averaging. *arXiv preprint arXiv:1602.05629*, 2:2.
- Reddy, K. D. and Gadekallu, T. R. (2023). A comprehensive survey on federated learning techniques for healthcare informatics. *Computational Intelligence and Neuroscience*, 2023:8393990. Copyright © 2023 K. Dasaradharami Reddy and Thippa Reddy Gadekallu.
- Souza, A., Bittencourt, L., Cerqueira, E., Loureiro, A., and Villas, L. (2023). Dispositivos, eu escolho vocês: Seleção de clientes adaptativa para comunicação eficiente em aprendizado federado. In *Anais do XLI Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 1–14, Porto Alegre, RS, Brasil. SBC.
- Xiang, M., Ioannidis, S., Yeh, E., Joe-Wong, C., and Su, L. (2024). Efficient federated learning against heterogeneous and non-stationary client unavailability. In *Advances in Neural Information Processing Systems*.
- Yan, Y., Niu, C., Ding, Y., Zheng, Z., Tang, S., Li, Q., Wu, F., Lyu, C., Feng, Y., and Chen, G. (2023). Federated optimization under intermittent client availability. *INFORMS Journal on Computing*, 36(1):185–202.
- Yao, D., Zhu, Z., Liu, T., Xu, Z., and Jin, H. (2024). Rethinking personalized federated learning from knowledge perspective. In *Proceedings of the 53rd International Conference on Parallel Processing*, pages 991–1000.
- Zhu, H., Xu, J., Liu, S., and Jin, Y. (2021). Federated learning on non-iid data: A survey. *Neuro-computing*, 465:371–390.